arXiv:1211.6851v1 [cs.LG] 29 Nov 2012

Classification Recouvrante Basée sur les Méthodes à Noyau

Chiheb-Eddine Ben N'Cir & Nadia Essoussi

LARODEC,Institut Supérieur de Gestion de Tunis, Université de Tunis
chiheb.benncir@gmail.com, nadia.essoussi@isg.rnu.tn

Abstract

Overlapping clustering problem is an important learning issue in which clusters are not mutually exclusive and each object may belongs simultaneously to several clusters. This paper presents a kernel based method that produces overlapping clusters on a high feature space using mercer kernel techniques to improve separability of input patterns. The proposed method, called OKM-K(Overlapping k-means based kernel method), extends OKM (Overlapping k-means) method to produce overlapping schemes. Experiments are performed on overlapping dataset and empirical results obtained with OKM-K outperform results obtained with OKM.

Résumé

Le problème de la classification recouvrante constitue un axe important de l'apprentissage automatique. Dans cet axe, les clusters ne sont pas mutuellement exclusifs et chaque objet peut appartenir simultanément à plusieurs groupes appelés recouvrements. Cet article présente une méthode à noyau permettant de produire des clusters non disjoints dans un espace de redescription fortement dimensionnel en utilisant les techniques de l'astuce de noyau pour améliorer la séparabilité du modèle de données initial. La méthode proposée, OKM-K(Overlapping k-means based kernel method) étend la méthode OKM(Overlapping k-means). Les expérimentations sont effectuées sur un ensemble de données recouvrantes et les résultats empiriques obtenus avec OKM-K sont meilleures que les résultats obtenus avec OKM.

mots clés: *Apprentissage et Classification, Data Mining, Méthodes à Noyau*

1 Introduction

Cet article s'intéresse au domaine de la classification recouvrante qui consiste à assigner des objets dans des classes non disjointes appelées recouvrements (Cleuziou , 2007). En effet, plusieurs problèmes réels nécessitent qu'un objet puisse appartenir à la fois à plusieurs partitions. Par exemple, en biologie, un gène peut participer à plusieurs processus ; en recherche d'information, un document peut aborder plusieurs thématiques ou appartenir à plusieurs genres différents ; en traitement du langage, un mot peut avoir plusieurs interprétations.

Plusieurs méthodes ont été proposées pour résoudre ce problème. Les premières méthodes étendent les schémas de classification floue où un objet appartient à plusieurs classes avec différents degrés d'appartenance(Deodhar and Ghosh,2006). En fixant un seuil minimal sur ces degrés, les objets sont affectés à une ou à plusieurs classes. Ces méthodes ne permettent pas de traiter tous les schémas de recouvrement possibles. Des méthodes plus récentes de classification recouvrante ont résolu ce problème en déterminant directement des recouvrements optimaux et non pas des partitions optimales. L'éventail de ces méthodes comprend à minima des généralisations des méthodes de réallocation dynamique telle que la méthode OKM proposée par Cleuziou (2008) , des adaptations des méthodes des mélanges de lois (Banerjee, 2005), (Heller and Ghahramani, 2007) et des méthodes fondées sur la théorie des graphes pour produire des schémas recouvrants (Fellows et al.,2009).

Dans cet article, nous nous intéressons à la construction des classes recouvrantes ainsi qu'à la détermination des séparations non sphériques entre les recouvrements. Nous proposons une méthode qui combine les avantages de la méthode OKM pour la construction directe des recouvrements optimaux et les avantages de la méthode kernel k-means(Camastra and Verri, 2005) pour la détermination des classes ayant des formes non shériques.

2 OKM: Overlapping k-means

La méthode OKM étend la méthode k-moyennes pour chercher des recouvrements optimaux plutôt que des partitions optimales. Etant donné un ensemble d'objets à classifier $X = \{x_i\}_{i=1}^N$ avec $x_i \in \Re^d$ et N le nombre d'objets, il s'agit de déterminer les k recouvrements de telle sorte que la fonction objective suivante soit optimisée :

$$J(\pi) = \sum_{x_i \in X} \|x_i - im(x_i)\|^2. \tag{1}$$

La notation $im(x_i)$ désigne l'image de x_i définie par la combinaison des centres des clusters auxquels x_i appartient :

$$im(x_i) = \sum_{c \in A_i} m_c / |A_i|, \tag{2}$$

où A_i est l'ensemble des affectations aux différents clusters de l'objet x_i, c'est-à-dire les clusters auquels x_i appartient et m_c correspond au centre du cluster c.

Le critère J de la fonction objective généralise le critère des moindres carrés utilisés dans la méthode k-moyennes. Pour minimiser ce critère, deux étapes principales sont exécutées itérativement tant que le critère J n'est pas minimisé. La première étape consiste à calculer les centres des clusters en utilisant la fonction $PROTOTYPE$ (Cleuziou, 2008). La deuxième étape consiste à affecter chaque objet à une ou à plusieurs classes selon la fonction d'affectation $ASSIGN$. La convergence de la méthode est caractérisée par

plusieurs critères à savoir le nombre d'itérations maximales et le seuil minimal d'amélioration de la fonction objective entre deux itérations.

La méthode OKM ne permet pas de déterminer les classes de formes concentriques et les classes de formes non sphériques. Pour résoudre ce problème, nous proposons d'étendre OKM en utilisant les méthodes à noyau.

3 OKM-K: Overlapping k-means based kernel method

Le critère d'erreur de cette méthode, tel que défini dans eq.(3), est optimisé dans un espace fortement dimensionnel pour améliorer la recherche des séparations entre les clusters.

$$J(\pi) = \sum_{x_i \in X} \|\phi(x_i) - im(\phi(x_i))\|^2, \tag{3}$$

avec $\phi(x_i)$ la représentation de l'objet x_i dans le nouvel espace. L'image $im(\phi(x_i))$ est aussi définie dans l'espace de redescription par:

$$im(\phi(x_i)) = \frac{\sum_{c=1}^{k} P_{ic}.m_c^{\phi}}{\sum_{c=1}^{k} P_{ic}}, \tag{4}$$

avec $P_{ic} \in \{0, 1\}$ une variable binaire indiquant l'appartenance de l'objet i au cluster c, et m_c^{ϕ} le prototype du cluster c dans l'espace de redescription. Le prototype d'un cluster est défini par le centre de gravité des objets qui appartiennent à ce cluster pondérés par le nombre de clusters auquels chaque objet appartient comme illustré dans eq.(5):

$$m_c^{\phi} = \frac{\sum_{j=1}^{N} P_{jc}.\phi(x_j).w_j}{W_c}, \tag{5}$$

avec W_c, la somme des poids des objets qui appartiennent au cluster c défini par $W_c = \sum_{j=1}^{N} P_{jc}.w_j$. La notation w_j indique le poids unitaire assigné à l'object j défini par $w_j = 1/(\sum_{c=1}^{k} P_{jc})^2$. A partir de cette définition des prototypes des clusters, le critère d'erreur

peut être calculé comme suit:

$$\begin{aligned} J(\pi) &= \sum_{x_i \in X} \|\phi(x_i) - \frac{1}{L_i}\sum_{c=1}^{k} P_{ic}.\frac{1}{W_c}\sum_{j=1}^{N} P_{jc}.w_j.\phi(x_j)\|^2 \\ &= \sum_{x_i \in X} \{\phi(x_i).\phi(x_i) - \frac{2}{L_i}\sum_{c=1}^{k}\sum_{j=1}^{N} P_{ic}.\frac{1}{W_c}.P_{jc}.w_j.\phi(x_i).\phi(x_j) + \\ &\quad \frac{1}{(L_i)^2}\sum_{c=1}^{k}\sum_{j=1}^{N}\sum_{t=1}^{k}\sum_{g=1}^{N} P_{ic}.\frac{1}{W_c}.P_{jc}.P_{it}.\frac{1}{W_t}.P_{gt}.w_j.w_g.\phi(x_j)\phi(x_g)\}, \end{aligned} \quad (6)$$

avec $L_i = \sum_{c=1}^{k} P_{ic}$. En remplaçant chaque produit scalaire dans l'espace de redescription par la fonction de noyau, le critère J peut être déterminé sans réellement définir les représentations $\phi(x_i)$:

$$\begin{aligned} J(\pi) &= \sum_{x_i \in X} \{K_{ii} - \frac{2}{L_i}\sum_{c=1}^{k}\sum_{j=1}^{N} P_{ic}.\frac{1}{W_c}.P_{jc}.w_j.K_{ij} + \\ &\quad \frac{1}{(L_i)^2}\sum_{c=1}^{k}\sum_{j=1}^{N}\sum_{t=1}^{k}\sum_{g=1}^{N} P_{ic}.\frac{1}{W_c}.P_{jc}.P_{it}.\frac{1}{W_t}.P_{gt}.w_j.w_g.K_{jg}\}, \end{aligned} \quad (7)$$

avec K_{ij} est la fonction de noyau représenant le produit scalaire entre $\phi(x_i)$ et $\phi(x_j)$. Pour optimiser le critère d'erreur, la méthode OKM-K affecte à chaque itération les représentations des objets $\phi(x_i)$ à un ou plusieurs clusters puis elle calcule de nouveau le critère J de la fonction objective. Si ce critère s'améliore d'une itération à une autre, les objets sont réaffectés aux clusters les plus proches jusqu'à l'optimisation de ce critère. Les conditions d'arrêt sont le nombre maximal d'itération et l'amélioration minimale dans la fonction objective d'une itération à une autre.

4 Expérimentations

Nous avons comparé l'efficacité de la méthode proposée OKM-K par rapport à la méthode OKM sur la la base de données $EachMovie$ [1] qui contient des évaluations en lignes des internautes pour certains films. Si chaque genre de film est considéré comme une classe contenant plusieurs films, alors cette base de données contient naturellement des classes recouvrantes. Un film peut appartenir à plusieurs genres. A partir de cet ensemble de données, nous avons construit un sous ensemble de jeu de données contenant 75 films

[1] http://www.grouplens.org/node/76.

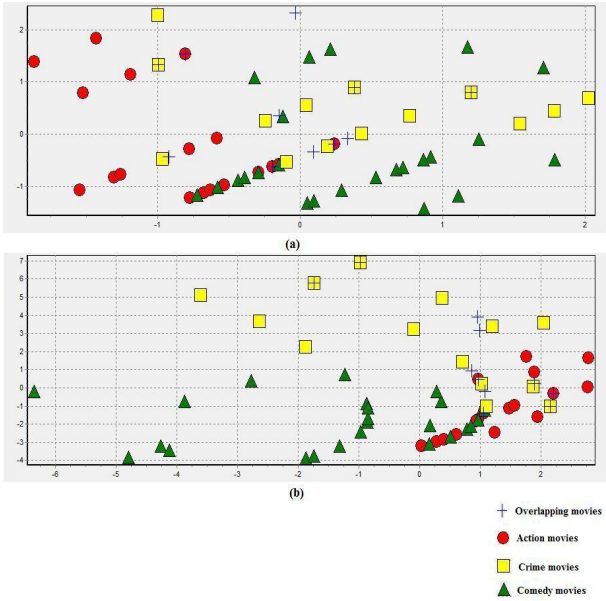

Figure 1: Représentation 2D d'un sous ensemble de la base *Eachmovie* contenant 3 genres de films sur les deux premiers axes en utilisant la méthode PCA: (a) données dans l'espace d'origine. (b) données dans l'espace de redescription.

répatis sur trois classes recouvrantes. La classe "Action" avec 21 films, la classe "Comédie" avec 26 films, la classe "Crime" avec 17 films et 11 films appartenant simultanément à la classe "Action" et "Crime". Le processus de classification dans ce sous ensemble consiste à déterminer le genre du film en se basant sur l'age, le sexe et la note d'évaluation des internautes. La figure 1.a montre la distribution des 3 genres de film sur les deux premiers axes en utilisant la méthode PCA. Les objets représentés avec "+" sont des films recouvrants qui appartiennent au genre "Action" et au genre "Crime". En projetant ces données dans un espace infiniment dimensionnel en utilisant un noyau RBF de paramètre $\sigma = 2$, nous remarquons une amélioration de la représentation des films recouvrants dans

Table 1: Comparaison entre la méthode OKM et la méthode OKM-K sur le dataset *Eachmovie*.

Méthode	Precision	Recall	F-measure
OKM avec distance euclidienne	0.557	0.788	0.616
OKM avec I-Divergence	0.582	0.687	0.630
OKM-K avec noyau polynomial (d=0.25)	**0.700**	0.615	0.665
OKM-K avec noyau RBF ($\sigma = 2$)	0.628	**0.851**	**0.721**

la figure 1.b puisque ces films recouvrants se trouvent à l'extrémité des films de type "Action" et les films de type "Crime".

Nous avons effectué dix exécutions de chaque méthode avec les mêmes initialisations des clusters dans chaque exécution. Le tableau 1. montre les différents résultats obtenus. Nous remarquons que la méthode OKM-K utilisée avec un noyau RBF donne la valeur "F-measure" la plus élevée. L'utilisation du noyau RBF a permis d'améliorer simultanément la mesure de précision et la mesure de rappel par rapport à la distance euclidienne.

5 Conclusion

Nous avons proposé dans cet article la méthode OKM-K qui permet explicitement de représenter les données dans un espace de dimensionnalité supérieur à l'espace d'origine par l'utilisation de l'astuce de noyau. La recherche des recouvrements optimaux est effectuée dans cet espace dimensionnel à travers la maximisation itérative d'une fonction objective. L'avantage de cette méthode consiste en sa capacité à identifier les clusters de formes non sphériques. Les résultats empiriques obtenus prouvent la performance de classification de la méthode OKM-K par rapport à la méthode OKM.

Comme travaux futurs, nous prévoyons de profiter de l'utilisation des méthodes à noyaux dans OKM-K pour appliquer la classification recouvrante sur des données structurées non vectorielles telles que les arbres et les histogrammes.

Bibliographie

[1] Banerjee, A., Krumpelman, C., Basu, S., Mooney, R. and Ghosh, J. (2005) Model based overlapping clustering. *In International Conference on Knowledge Discovery and Data Mining*, Chicago, USA. SciTePress.

[2] Camastra, F. and Verri, A. (2005) A novel kernel method for clustering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27:801-804.

[3] Cleuziou, G. (2007) Okm : une extension des k-moyennes pour la recherche de classes recouvrantes. *Revue des Nouvelles Technologies de l'Information*, Cpadus-Edition RNTI-E, 2:691-702.

[4] Cleuziou, G. (2008) An extended version of the k-means method for overlapping clustering. *In International Conference on Pattern Recognition ICPR*, pages 1-4, Florida, USA. IEEE.

[5] Deodhar, M. and Ghosh, J. (2006) Consensus clustering for detection of overlapping clusters in microarray data. *workshop on data mining in bioinformatics. In International Conference on data mining*, pages 104-108, Los Alamitos, CA, USA. IEEE Computer Society.

[6] Fellows, M. and Guo, J., Komusiewicz, C., Niedermeier, R., Uhlmann, J. (2009) Graph-Based Data Clustering with Overlaps. *Computing and Combinatorics*, 516–526,USA.

[7] Heller, K. and Ghahramani, Z. (2007) A nonparametric bayesian approach to modeling overlapping clusters. *11th International Conference on Artifical Intelligence and Statistics*, San Juan, Puerto Rico.